

PROMESSAS E DESAFIOS PARA A DETERMINAÇÃO DA MATURAÇÃO DA CANA- DE-AÇÚCAR UTILIZANDO SENSORIAMENTO REMOTO POR SATÉLITES: UMA REVISÃO SISTEMÁTICA DA PESQUISA

**PROMISES AND CHALLENGES FOR DETERMINING SUGARCANE
MATURATION USING SATELLITE REMOTE SENSING: A SYSTEMATIC
REVIEW OF THE RESEARCH**

Ciências Agrárias, Engenharias • 01/08/2026

REGISTRO DOI: [10.70773/revistatopicos/785283721](https://doi.org/10.70773/revistatopicos/785283721)

Rogério Pereira Simões¹

Geraldo Antônio de Oliveira²

Josemar Alves dos Santos Júnior³

Lucas Peres Angelini⁴

RESUMO

Nos últimos anos, vários estudos foram publicados explorando a aplicação de técnicas de sensoriamento remoto por satélites na cultura da cana-de-açúcar com o objetivo de otimizar a produção, monitorar as condições hídricas e prever a qualidade da matéria-prima contribuindo para um manejo eficiente, sustentável e lucrativo. O sensoriamento remoto, com base em estudos e revisões atuais, surge como uma alternativa promissora, fornecendo dados espaciais e temporais que aliados a técnicas eficientes de análise de dados e aprendizado de máquina (LM) contribuem para uma determinação mais precisa do ponto de maturação, sugerindo um momento ideal para a colheita. Este estudo fornece uma visão geral da pesquisa sobre a utilização de sensoriamento remoto por satélites no cultivo de cana-de-açúcar discutindo os avanços e desafios das abordagens, descrevendo, também, a confiabilidade dos dados fornecidos pelos satélites Landsat e Sentinel-2 que permitem monitoramento econômico de vários fatores no cultivo da cana-de-açúcar, principalmente os relacionados à maturação, fornecendo informações espectrais e multitemporais bastante precisas, permitindo abordagens poderosas de aprendizado de máquina (LM) como o algoritmo de floresta aleatória (RF) para determinação eficiente do crescimento, saúde e rendimento da cana-de-açúcar.

Palavras-chave: Cana-de-açúcar; Índice de Maturidade; Sensoriamento Remoto por Satélite.

ABSTRACT

In recent years, several studies have been published exploring the application of satellite remote sensing techniques in sugarcane cultivation with the aim of optimizing production, monitoring water conditions and predicting the quality of raw material contributing to

efficient, sustainable and profitable management. Remote sensing, based on current studies and reviews, emerges as a promising alternative, providing spatial and temporal data that, combined with efficient data analysis and machine learning (ML) techniques, contribute to a more accurate determination of the maturity point, suggesting an ideal time for harvesting. This study provides an overview of the research on the use of satellite remote sensing in sugarcane cultivation, discussing the advances and challenges of the approaches, also describing the reliability of the data provided by the Landsat and Sentinel-2 satellites that allow cost-effective monitoring of several factors in sugarcane cultivation, mainly those related to maturity, providing very accurate spectral and multitemporal information, allowing powerful machine learning (ML) approaches such as the random forest (RF) algorithm for efficient determination of sugarcane growth, health and yield.

Keywords: Sugarcane; Maturity Index; Satellite Remote Sensing.

1. INTRODUÇÃO

A cana-de-açúcar (*Saccharum spp.*) é uma das principais culturas agrícolas do Brasil, desempenhando um papel estratégico na economia nacional devido à sua relevância para os setores sucroenergético e alimentício. O país é o maior produtor mundial cana-de-açúcar com 685,86 milhões de toneladas, em uma área de 8673,1 mil hectares (CONAB, 2024). Além de impulsionar a balança comercial, a cadeia produtiva da cana-de-açúcar gera milhões de empregos diretos e indiretos, contribuindo para o desenvolvimento socioeconômico de diversas regiões.

Dado o tamanho e a importância dessa cultura, a qualidade da matéria-prima é um fator primordial para aumento de produção. No

entanto, a otimização da produção e a garantia da qualidade da matéria-prima representam desafios constantes para o setor sucroenergético (DIMOV et. al, 2022). Nesse contexto, a determinação precisa do índice de maturação e a identificação do momento ideal para a colheita são etapas fundamentais para maximizar o rendimento e a qualidade do produto final (VELÁZQUEZ et. al, 2023). Tradicionalmente, esse processo é realizado por meio de amostragens em campo e análises laboratoriais, métodos que, embora eficazes, são custosos, demorados e sujeitos a variações espaciais significativas mostrando-se limitados em termos de escala e representatividade espacial (LEANDRO et. al, 2024).

Em contrapartida, o sensoriamento remoto (SR) emerge como uma ferramenta promissora, oferecendo dados espaciais e temporais detalhados sobre as lavouras (KHARAMOV et. al, 2020). A combinação estratégica do SR com técnicas de aprendizado de máquina (ML) permite o desenvolvimento de modelos preditivos robustos, capazes de estimar o índice de maturação e identificar o momento ótimo para a colheita com maior precisão e eficiência (LIAGHAT et. al, 2019).

A aplicação de imagens de satélite na agricultura de precisão permite estimar variáveis biofísicas da cultura, como teor de clorofila, teor de biomassa e índice de área foliar, que estão diretamente relacionadas ao acúmulo de sacarose nos colmos. Métodos baseados em índices de vegetação, como o NDVI (Índice de Vegetação por Diferença Normalizada) e o EVI (Índice de Vegetação Aprimorado), têm sido amplamente utilizados para avaliar a maturação da cana, permitindo que produtores e indústrias tomem decisões estratégicas sobre o momento ideal da colheita.

Este artigo de revisão tem como objetivo explorar o potencial transformador do SR e do ML na cultura da cana-de-açúcar, com foco na otimização do índice de maturação e na determinação do momento ideal para a colheita. Foram abordados os principais índices de vegetação utilizados, as metodologias de modelagem da maturação com ML, o uso de indutor de maturação e o monitoramento temporal da qualidade da cana-de-açúcar, visando fornecer aos produtores e pesquisadores uma visão abrangente das ferramentas e técnicas disponíveis para aprimorar a gestão da cultura e garantir o atendimento da crescente demanda global por açúcar e bioenergia (BARBOSA JÚNIOR, et. al, 2024).

2. MATERIAS E MÉTODOS

2.1. Critérios de Busca e Seleção


Em revisões de pesquisas vários métodos são utilizados para a seleção das fontes de estudo que serão analisadas. Para esta revisão foram selecionados artigos em inglês sobre fenologia, evapotranspiração e maturação da cana-de-açúcar, bem como , artigos que discorrem do uso de sensoriamento remoto por satélite, aprendizado de máquina(ML), imagens multiespectrais e termográficas e tratamento de dados.

A plataforma escolhida com banco de dados de periódicos publicados sobre o assunto foi a Sciencedirect utilizando palavras-chave como: *“satellite remote sensing of sugarcane”*, *“sugarcane and ML”* e *“determination of the sugarcane maturity index”*.

Na primeira busca efetuada foram encontrados 1595 resultados. Em seguida a busca foi refinada para artigos publicados nos últimos 6 anos encontrando 907 resultados. Um filtro para seleção de artigos

científicos de pesquisa foi marcado encontrando 644 resultados . E finalmente a busca foi refinada com o título da publicação “*remote sensing applications: Society and enviroments*” encontrando 30 artigos. Após o download dos artigos encontrados 12 artigos foram selecionados pelo critério de relevância e adequados para a inclusão neste estudo.

Figura 1. Processo de seleção dos artigos da revisão bibliográfica.



Fonte: Elaborado pelo autor.


2.2. Análise de Dados

Analizando qualitativamente o conteúdo dos 12 artigos selecionados no estudo podemos perceber várias vantagens e desafios para a determinação da maturação da cana-de-açúcar por meios remotos utilizando imagens espectrais obtidas de satélites.

No primeiro artigo analisado de CHAUDHARI et. al (2023) há uma discussão sobre a previsão de rendimento da cana-de-açúcar utilizando uma combinação de dados de sensoriamento remoto óptico e de radar de abertura sintética (SAR), onde o objetivo principal é melhorar a precisão das estimativas de biomassa e rendimento da cana-de-açúcar. O estudo integrou dados do Sentinel-1 (SAR) e Sentinel-2 (óptico) para modelagem usando vários

algoritmos de aprendizado de máquina, incluindo técnicas de ensemble como bagging e boosting. A fusão de dados ópticos e SAR melhorou a precisão das previsões, com a modelagem explicando 63-70% da variação na biomassa durante o treinamento e 44-60% nos testes.

Figura 2. Breve esboço da metodologia.




Fonte: Adaptado de Chaudhari et. al (2024).

Numa outra abordagem LEANDRO et. al (2024) discute o uso de imagens de sensoriamento remoto de alta resolução espacial para estimar a maturidade da cana-de-açúcar. A pesquisa teve como objetivo desenvolver um método mais eficiente e econômico para monitorar a maturidade da cana durante seu ciclo de crescimento, especialmente devido aos impactos das mudanças climáticas. O estudo utilizou imagens capturadas por drones equipados com uma câmera multispectral. Foram coletadas amostras de campo para medir valores de Brix e pol. Índices de vegetação como NDWI, GNDVI e a banda verde foram selecionados com base na correlação

com as amostras de campo. Três modelos de regressão foram empregados: Random Forest (RF), Support Vector Machine (SVM), e uma regressão linear múltipla. O modelo RF apresentou o melhor desempenho em termos de precisão e acurácia. A análise indicou que a área de estudo ainda não havia atingido a maturidade ideal para a colheita. O método desenvolvido é eficaz para o monitoramento temporal das culturas e otimiza o tempo de colheita.

Figura 3. Comparação dos mapas de índice de maturidade gerados pelos modelos de regressão linear múltipla, máquina de vetor de suporte e floresta aleatória.




Fonte: Adaptado de Leandro et. al (2024).

DIMOV et. al (2022) aborda o uso de séries temporais de sensoriamento remoto e métricas de fenologia para estimar a produtividade da cana-de-açúcar. O objetivo de estimar a produtividade da cana-de-açúcar é implementar estratégias de otimização, facilitar o planejamento da logística de colheita, verificar a confiabilidade das estimativas de pré-colheita e otimizar o preço

da commodity de acordo com sua disponibilidade. O estudo compara três conjuntos de variáveis preditoras: séries temporais de índices de vegetação, métricas fenológicas e variáveis espaço-temporais. Utiliza modelos de regressão, incluindo Random Forest (RF) e Support Vector Machine (SVM). O modelo RF apresentou os melhores resultados, alcançando coeficientes de determinação (R^2) de até 0,84 para a estimativa de rendimento e 0,82 para a quantidade de açúcar. As métricas fenológicas mostraram-se particularmente eficazes e poderiam ser úteis para transferência de modelos.

Figura 4. Comparação dos níveis de saturação dos índices de vegetação NDVI, NDRE1 e CIRE.



Fonte: Adaptado de Dimov et. al (2022).


Um outro aspecto, muito importante, abordado em SILVEIRA et. al (2020) é o uso de imagens multiespectrais e termográficas para monitorar as condições hídricas da cana-de-açúcar enfatizando a importância da irrigação na produtividade da cultura. As imagens termográficas têm potencial para avaliação rápida, não destrutiva e eficiente do estado hídrico das plantas de cana-de-açúcar.

O sensoriamento remoto pode ser usado para estimar a biomassa e a produtividade da cultura, monitorar o estresse hídrico e o vigor nas plantas e avaliar o estágio fenológico. As imagens termográficas podem expressar alterações no estado hídrico mais precocemente do que os dados de NDVI obtidos por imagens multiespectrais.

Utilizaram-se drones equipados com câmeras multiespectrais e termográficas para capturar imagens da área de cultivo irrigada e não irrigada. As imagens foram processadas para gerar mapas de temperatura e índices de vegetação, como o NDVI. As análises mostraram diferenças significativas entre as áreas irrigadas e não irrigadas.

As imagens termográficas identificaram temperaturas mais baixas nas áreas irrigadas, indicando melhor estado hídrico. O NDVI também evidenciou maior vigor nas plantas irrigadas.

Figura 5. Índices de vegetação (NDVI) da área experimental em diferentes estágios de desenvolvimento da cana-de-açúcar.




Fonte: Adaptado de Silveira et. al (2020).

O uso de machine learning e sensoriamento remoto para monitorar a maturação da cana-de-açúcar é abordado em VELÁZQUEZ et. al (2023). Métodos destrutivos e de laboratório são normalmente usados para prever a qualidade do suco da cana, e o sensoriamento remoto é uma fonte potencial de dados para monitorar as colheitas, fornecendo informações espaciais e temporais. Os algoritmos de aprendizado de máquina, como florestas aleatórias (RF), máquina de vetores de suporte (SVM) e regressão linear múltipla (MLR), podem ser usados para estimar os parâmetros de qualidade do suco de cana-de-açúcar. As imagens multiespectrais do Sentinel 2

permitiram estimar todos os índices de vegetação em estudo com uma resolução espacial de 10 m. Imagens do Sentinel-2 foram processadas para calcular índices de vegetação como NDVI, SAVI e GNDVI. Medidas de qualidade do suco foram coletadas mensalmente em parcelas experimentais. Foram encontradas correlações significativas ($>0,70$) entre os índices de vegetação e os parâmetros de qualidade do suco. O modelo de machine learning Random Forest apresentou o melhor desempenho na previsão dos parâmetros de qualidade em comparação com outros modelos.


Figura 6. Evolução temporal dos índices de vegetação relacionados ao teor de clorofila na área de estudo.



Fonte: Adaptado de Velázquez et. al (2023).

SHAKIR (2023) concentra suas pesquisas sobre um modelo otimizado de monitoramento da cultura da cana-de-açúcar utilizando aprendizado profundo e imagens de sensoriamento remoto. O objetivo é melhorar a estimativa de produtividade da cana-de-açúcar através da análise de dados obtidos de satélites, como o Sentinel-2. O estudo propõe o modelo ODLD-SSCM (Optimal Deep Learning Driven Smart Sugarcane Crop Monitoring), que utiliza um modelo de aprendizado profundo com autoatenção (SADL) e um algoritmo de otimização (OSCO) para ajuste de hiperparâmetros. O modelo visa mapear o rendimento da cana-de-açúcar a partir de imagens de sensoriamento remoto. O modelo ODLD-SSCM alcançou coeficientes de determinação (R^2) de até 0,84 e erros quadráticos médios (RMSE) reduzidos, demonstrando eficácia em prever a produtividade da cana-de-açúcar. Comparações com outros métodos mostraram que o ODLD-SSCM teve desempenho superior.


Figura 7. Análise do coeficiente de determinação (R^2) da abordagem ODLD-SSCM para os conjuntos de treinamento, teste e dados completos.



Fonte: Adaptado de Shakir (2023).

KHRAMOV et. al (2020) discute o uso de dados ópticos e SAR para monitorar a colheita de cana-de-açúcar no Brasil. Seu estudo apresenta algoritmos para determinar as datas de colheita da cana-de-açúcar, utilizando dados públicos de radar de abertura sintética (SAR) e satélites ópticos, como o Sentinel-1 e Sentinel-2. O primeiro algoritmo utiliza a série temporal do Índice de Vegetação por Diferença Normalizada (NDVI) do Sentinel-2. Uma queda acentuada no NDVI indica a colheita e o segundo algoritmo baseado em séries temporais de coerência do Sentinel-1, identifica períodos de baixa coerência que correspondem à colheita. Os resultados foram satisfatórios tendo o algoritmo baseado em dados ópticos uma taxa de coincidência de 97% com a interpretação visual das datas de colheita, enquanto o algoritmo que combina dados SAR e ópticos 90%.


Figura 8. Comparação de área de cana-de-açúcar antes e após a colheita em imagem natural e NDVI.



Fonte: Adaptado de Khramov et al. (2020).

A presença de nuvens e a variação nas condições climáticas dificultam a precisão das medições. O uso combinado de dados ópticos e SAR melhora a identificação das datas de colheita, especialmente em períodos de alta nebulosidade. Os algoritmos podem ser utilizados para monitorar operações de colheita, estimar áreas colhidas e contribuir para a previsão de produtividade no setor sucroalcooleiro.


Figura 9. Efeito da nebulosidade sobre imagens da área de estudo durante o período de colheita.



Fonte: Adaptado de Khramov et al. (2020).

LIAGHAT et. al (2019) aborda o uso do sensoriamento remoto para otimizar a colheita da cana apresentando um modelo na determinação do melhor momento para a colheita de quatro variedades de cana-de-açúcar, utilizando índices de vegetação obtidos de imagens de satélite. O objetivo do estudo se concentra na melhoria da gestão da colheita de cana-de-açúcar focando na maximização do conteúdo de sacarose (pol) otimizando a identificação do momento de colheita e criar um mapa de zoneamento para áreas prontas para a colheita. Foram utilizadas imagens do Landsat-8 para calcular índices de vegetação, como NDVI (Índice de Vegetação por Diferença Normalizada), GVI (Índice de Vegetação Verde) e GNDVI (Índice de Diferença Normalizada Verde), para estimar o conteúdo de sacarose e a correlação entre esses índices e o pol foi analisada. O GNDVI apresentou a maior correlação com o pol ($R^2 = 0,885$), indicando que valores entre 0,50 e 0,55 são ideais para a colheita. Um mapa de zoneamento foi desenvolvido, categorizando áreas como prontas para colheita, colheita atrasada e não prontas.

Figura 10. Correlação entre o índice de vegetação GNDVI e o teor de sacarose (Pol) em diferentes variedades de cana-de-açúcar.




Fonte: Adaptado de Liaghat et. al (2019).

BARBOSA JÚNIOR et. al (2024) discute o uso de sensoriamento integrado e aprendizado de máquina para prever sacarina e matérias-primas de bioenergia na cana-de-açúcar. O objetivo do estudo é desenvolver um framework preditivo não invasivo para mapear os insumos da cana-de-açúcar, focando na previsão de açúcares (para bioetanol de primeira geração) e componentes lignocelulósicos (para bioetanol de segunda geração). Foram utilizadas imagens de drones equipadas com câmeras multiespectrais, dados térmicos e de fluorescência de clorofila. Foram aplicados modelos de aprendizado de máquina, incluindo Random Forest (RF), Regressão Linear Múltipla (MLR), Árvore de Decisão (DT) e Máquinas de Vetores de Suporte (SVM). Os modelos de ML mostraram boa precisão na previsão dos insumos, com coeficientes de determinação (R^2) variando de 0,88 a 0,93 para açúcares de 1G e de 0,56 a 0,82 para insumos de 2G. Dados de sensoriamento remoto, especialmente nas bandas espectrais Blue,

Green e RedEdge, foram identificados como características importantes para as previsões. A pesquisa destaca a importância do uso de sensoriamento remoto e aprendizado de máquina para otimizar o momento da colheita, ajudando a aumentar a qualidade dos produtos e a eficiência do processo de produção de bioenergia.


Figura 11. Arquitetura dos modelos de aprendizado de máquina.



Fonte: Adaptado de Barbosa Júnior et. al (2024).

VILARREAL et. al (2020) aborda o uso de técnicas de sensoriamento remoto para classificar e mapear Os estágios de crescimento da cana-de-açúcar auxiliando na gestão eficiente do cultivo. A pesquisa empregou a Análise de Imagem Baseada em Objetos (OBIA) combinada com dados de LiDAR e ortofotos. Foi utilizado o algoritmo de Máquinas de Vetores de Suporte (SVM) para a classificação, validada por GPS. A classificação alcançou uma precisão de 98,4%, mapeando 13,93 hectares de plantação. Os estágios de crescimento identificados foram: estabelecimento (6,65%), tillering (11,61%), formação de rendimento (13,89%) e maturação (17,90%). As precisões para os estágios foram: 88% (estabelecimento), 94,4% (tillering), 96,3% (formação de rendimento) e 91,7% (maturação). Os resultados demonstram a eficácia do uso de técnicas de sensoriamento remoto na identificação precisa dos estágios de crescimento da cana-de-açúcar, o que pode ajudar na tomada de decisões sobre o momento ideal para a colheita e gerenciamento das plantações.

Figura 12. Mapa de cobertura do solo dos estágios de crescimento da cana-de-açúcar processada.




Fonte: Adaptado de Vilarreal et. al (2020).

ELKINA et. al (2020) investiga a previsão de rendimento da cana-de-açúcar utilizando tecnologia de sensoriamento remoto e algoritmos de aprendizado de máquina. A implementação de modelos de previsão baseados em Random Forest (RF) e regressão polinomial de segundo grau, utilizando dados do satélite Sentinel-2 e informações agronômicas coletadas durante a safra 2017-2018, revelaram que o índice de vegetação normalizado verde (GNDVI) apresentou a melhor correlação com o rendimento, com um R^2 de 0,71 em novembro. O modelo RF alcançou uma precisão de 90,42%, enquanto a regressão polinomial obteve 88%. Esses resultados

indicam que ambos os modelos são eficazes para auxiliar no planejamento operacional das usinas de açúcar. Os autores destacam a importância do momento da aquisição das imagens para a previsão do rendimento, sugerindo que novembro é o período mais apropriado. O artigo conclui que a combinação de índices de vegetação e técnicas avançadas de modelagem pode aprimorar a previsão do rendimento da cana-de-açúcar, ressaltando a necessidade de mais pesquisas para validar esses modelos em diferentes contextos e variedades de cultivo.

Figura 13. Comparação entre os rendimentos reais e os estimados pelo modelo de regressão baseado em GNDVI.




Fonte: Adaptado de Elkina et. al (2020).

SHARMA et. al (2024) apresenta uma abordagem integrada para melhorar a gestão agrícola na Índia, utilizando técnicas de sensoriamento remoto e a Internet das Coisas (IoT). O estudo se concentra em duas abordagens principais: a primeira utiliza descritores de sensoriamento remoto, como índices de umidade e temperatura do solo, para identificar áreas com déficit hídrico; a segunda implanta sensores de umidade conectados a microcontroladores para monitoramento em tempo real. Os dados

foram coletados ao longo de um período de dez anos (2015-2024) utilizando imagens do satélite Sentinel-2. A pesquisa resultou na criação do sistema "SMARTS" (Sustainable Management and Agriculture Resource Technology System), que alcançou uma precisão de 97,24% nas alertas de umidade. O sistema é escalável e adaptável a diferentes locais, oferecendo uma base sólida para práticas agrícolas sustentáveis. O estudo também aborda a importância de monitorar as condições climáticas e a umidade do solo, considerando a crescente irregularidade climática e os desafios enfrentados pelos agricultores. A integração de sensoriamento remoto e IoT visa proporcionar uma gestão agrícola mais eficiente e sustentável, contribuindo para a segurança alimentar e o bem-estar dos agricultores.

Figura 14. Microcontrolador Uno e sensor de umidade do solo.



Fonte: Adaptado de Sharma et. al (2024).

3. RESULTADOS E DISCUSSÃO

Os resultados obtidos nas investigações sobre o uso de sensoriamento remoto e aprendizado de máquina na determinação da maturação da cana-de-açúcar revelam avanços significativos, mas também destacam desafios que precisam ser superados.

3.1. Benefícios para a Agricultura

A integração do sensoriamento remoto por satélite na gestão agrícola oferece diversos benefícios:

- **Monitoramento Contínuo:** Permite a observação regular das culturas, identificando rapidamente quaisquer anomalias ou necessidades específicas.
- **Otimização de Recursos:** Auxilia na aplicação precisa de insumos, como fertilizantes e irrigação, com base nas necessidades reais das plantas.
- **Planejamento da Colheita:** Fornece informações sobre o estágio de maturação, auxiliando na determinação do momento ideal para a colheita e garantindo a qualidade do produto.

3.2. Avanços na Aplicação de Sensoriamento Remoto

Estudos como o de CHAUDHARI et al. (2023) mostraram que a combinação de dados de sensoriamento remoto óptico e de radar de abertura sintética (SAR) pode melhorar a precisão das estimativas de biomassa e rendimento da cana-de-açúcar. A fusão de dados de diferentes fontes proporciona uma visão mais abrangente, permitindo a modelagem de variáveis complexas que afetam o crescimento da cultura. Além disso, a pesquisa de LEANDRO et al. (2024) destaca a eficácia das imagens de alta resolução espacial, apesar das imagens neste estudo terem capturadas por drones existem satélites como o CBERS4A e o Sentinel-2 que podem que foram utilizadas para monitorar a maturidade da cana-de-açúcar. A utilização de modelos de aprendizado de máquina, como a floresta

aleatória, demonstrou ser uma abordagem eficiente para prever o índice de maturação, aumentando a precisão na determinação do momento ideal para a colheita.

3.3. Integração de Tecnologias

A integração de sensoriamento remoto e aprendizado de máquina, como discutido por BARBOSA JÚNIOR et al. (2024), mostra-se promissora para a previsão de açúcares. A utilização de imagens sensoriais e dados térmicos permite desenvolver um framework preditivo não invasivo, que pode ser adaptado para diferentes condições de cultivo.

3.4. Eficiência Energética

A adoção de tecnologias de sensoriamento remoto e algoritmos de aprendizado tem potencial significativo para aumentar a eficiência energética na cultura da cana-de-açúcar, sobretudo ao otimizar o momento da colheita reduzindo o uso de insumos e o uso excessivo de maquinário agrícola evitando gasto energético com operações repetitivas (LEANDRO et al., 2024).

Segundo Dimov et al. (2022), os modelos de predição de produtividade que utilizam séries temporais de índices de vegetação e métricas fenológicas contribuem para um planejamento agrícola mais eficaz, incluindo a estimativa de rendimento e o dimensionamento da logística de colheita. Ao prever com antecedência o volume de produção, é possível otimizar o uso de transportes e infraestrutura de processamento, reduzindo o gasto energético associado ao armazenamento e ao transporte desnecessário de biomassa.

3.5. Desafios Enfrentados

Apesar dos avanços, ainda existem desafios significativos. A variabilidade climática e as condições atmosféricas, como a presença de nuvens, dificultam a obtenção de dados precisos. A pesquisa de KHRAMOV et al. (2020) enfatiza que a combinação de dados ópticos e SAR é uma estratégia eficaz para superar esses obstáculos, melhorando a identificação das datas de colheita, especialmente em períodos de alta nebulosidade. Além disso, a necessidade de validação dos modelos em diferentes contextos e variedades de cana-de-açúcar é crucial. A disponibilidade e o pré-processamento demorado de séries temporais, também são desafios a serem superados. O trabalho de ELKINA et al. (2020) sugere que a precisão das previsões de rendimento depende fortemente do momento da aquisição das imagens, o que exige um planejamento cuidadoso para maximizar a eficácia dos dados obtidos.

3.6. Implicações Práticas

Os resultados das pesquisas indicam que o uso de sensoriamento remoto e técnicas de aprendizado de máquina não apenas otimiza a determinação do índice de maturação, mas também pode impactar significativamente a gestão agrícola, contribuindo para uma produção mais sustentável e lucrativa.

A implementação dessas tecnologias pode ajudar os produtores a atenderem à crescente demanda por açúcar e bioenergia, melhorando a eficiência dos processos produtivos.

4. CONCLUSÕES

A revisão resume diferentes aplicações da tecnologia de sensoriamento remoto no setor de cana-de-açúcar. Os artigos demonstraram um panorama promissor, que pode transformar a gestão agrícola e elevar a eficiência produtiva do setor sucroalcooleiro.

As tecnologias de sensoriamento remoto, aliadas a algoritmos de aprendizado de máquina, oferecem uma nova abordagem para a monitoração e avaliação das condições das lavouras, superando limitações dos métodos tradicionais que, embora eficazes, são custosos e demorados.

Os estudos revisados indicam que a fusão de dados provenientes de diferentes fontes, como imagens ópticas e de radar, resulta em estimativas mais precisas sobre o crescimento e a saúde das plantas sendo extremamente importantes para avaliar o momento ideal da colheita, fundamental para maximizar a qualidade da matéria-prima e a rentabilidade do cultivo.

Entretanto, a implementação dessas tecnologias não está isenta de desafios. A variabilidade climática, a presença de nuvens e a necessidade de validação em diferentes contextos agronômicos ainda representam barreiras a serem superadas. A necessidade de um planejamento estratégico na aquisição de dados e a adaptação dos modelos às particularidades locais são cruciais para a eficácia das previsões. A literatura destaca que a precisão dos modelos pode ser significativamente influenciada pelo momento da coleta de dados, o que exige um entendimento profundo das dinâmicas agrícolas.

Além disso, a integração de tecnologias emergentes, como a Internet das Coisas (IoT), conforme discutido por SHARMA et al. (2024), pode potencializar ainda mais a gestão agrícola, permitindo o monitoramento em tempo real das condições das lavouras. Essa abordagem integrada não só melhora a resposta dos agricultores às condições climáticas variáveis, mas também contribui para práticas agrícolas mais sustentáveis, alinhadas com a crescente demanda global por açúcar e bioenergia.

Portanto, a continuidade das pesquisas nesse campo é essencial. O desenvolvimento de modelos mais robustos, a validação em diferentes regiões e a adaptação às especificidades de cada cultivar irão garantir que as tecnologias de sensoriamento remoto e aprendizado de máquina cumpram seu potencial transformador. A adoção dessas inovações poderá não apenas otimizar a produção de cana-de-açúcar, mas também contribuir para a sustentabilidade econômica e ambiental do setor, promovendo um futuro mais eficiente e rentável para a agricultura.

REFERÊNCIAS BIBLIOGRÁFICAS

BARBOSA JÚNIOR, M.R. et al, *Integrated sensing and machine learning: Predicting saccharine and bioenergy feedstocks in sugarcane*, v. 215, 2024. Disponível em: <https://doi.org/10.1016/j.indcrop.2024.118627>. Acesso em 17 fev. 2025.

CHAUDHARI, K. et al, *Machine learning model ensemble for predicting sugarcane yield through Synergy of optical and SAR remote sensing*, v. 30, 2023. Disponível em: <https://doi.org/10.1016/j.rsase.2023.100962>. Acesso em 12 fev. 2025.

COMPANHIA NACIONAL DE ABASTECIMENTO – CONAB. Safra 2024/2025. Primeiro Levantamento (abril/2024). Disponível em: <http://www.conab.gov.br>. Acesso em : 17 Fev. 2025.

DIMOV, D. et al, *Sugarcane yield estimation through remote sensing time series and phenology metrics*, v. 2, 2022. Disponível em: <https://doi.org/10.1016/j.atech.2022.100046>. Acesso em 13 fev. 2025.

ELKINA, E. et al, *Sugarcane Yield Prediction Using Vegetation Indices in Northern Karnataka, India*, v. 10, 2022. Disponível em: <https://doi.org/10.13189/ujar.2022.100611>. Acesso em 17 fev. 2025.

KHRAMOV, D. et al, *Monitoring of sugarcane harvest in Brazil based on optical and Sar data*, v. 12, 2020. Disponível em: <https://doi.org/10.3390/rs12244080>. Acesso em 14 fev. 2025.

LEANDRO, E. R.. et al, *Estimating sugarcane maturity using high spatial resolution remote sensing images*, v. 4 333-347 p, 2024. Disponível em: <https://doi.org/10.3390/crops4030024>. Acesso em 12 fev. 2025.

LIAGHAT, A. et al, *Optimization of sugarcane harvest using remote sensing*, int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci., XLII-4/W18, 857–861, 2019. Disponível em: <https://doi.org/10.5194/isprs-archives-XLII-4-W18-857-2019>. Acesso em 17 fev. 2025.

SHAKIR, A.K. , *Optimal Deep Learning Driven Smart Sugarcane Crop Monitoring on Remote Sensing Images*, v. 2023 n. 2, 2023. Disponível em: [jsiot-2022-0011](https://doi.org/10.1155/2022/2022-0011). Acesso em 14 fev. 2025.

SHARMA, N. et al, *Sustainable management and agriculture resource technology system using remote sensing descriptors and*

IoT, v. 76, 2024. Disponível em:
<https://doi.org/10.1016/j.geomat.2024.100040>. Acesso em 17 fev. 2025.

SILVEIRA, J. M. C. et al, *Uso de imagens multiespectrais e termográficas para monitoramento das condições hídricas da cana-de-açúcar*, v. 25 n4 689-696 p, 2020. Disponível em:
<https://doi.org/10.15809/irriga.2020v25n4p689-696>. Acesso em 13 fev. 2025.

VELÁZQUEZ, S. S.. et al, *Machine learning and remote sensing to monitor the maturation of sugarcane* in Conference El machine learning y la teledetección para monitorear la maduración de la caña de azúcar, 2023, Michoacan, México .Disponível em:
<https://www.researchgate.net/publication/378654780>. Acesso em 13 fev. 2025.

VILARREAL, M.K.. et al, *Remote sensing techniques for classification and mapping of sugarcane growth*, v. 10, 2020. Disponível em:
<https://doi.org/10.48084/etasr.3694>. Acesso em 17 fev. 2025.

¹ Instituto Federal Goiano, Campus Rio Verde, Rio Verde - Go, Brasil.
E-mail: [acesse o artigo original para visualizar o e-mail](#)

² Instituto Federal de Educação Ciência e Tecnologia do Espírito Santo- IFES, Campus Presidente Kennedy Presidente Kennedy – ES, Brasil. E-mail: [acesse o artigo original para visualizar o e-mail](#)

³ Instituto Federal de Goiano - Campus Morrinhos, Morrinhos – Go, Brasil. E-mail: [acesse o artigo original para visualizar o e-mail](#)

⁴ Instituto Federal de Goiás - Campus Itumbiara, Itumbiara – Go, Brasil. E-mail: [acesse o artigo original para visualizar o e-mail](#)

⁵ Instituto Federal de Goiás - Campus Itumbiara, Itumbiara – Go, Brasil. E-mail: [acesse o artigo original para visualizar o e-mail](#)

⁶ Instituto Federal Goiano - Campus Rio Verde, Rio Verde – Go, Brasil. E-mail: [acesse o artigo original para visualizar o e-mail](#)